

FCM을 이용한 고장전류의 판별에 관한 연구

정종원, 지식준, 이준탁*, 김광백**

*동아대학교, **신라대학교

Faults Current Discrimination Using FCM

Jong-Won Jeong, Suk-Joon Ji, Joon-Tark Lee*, Kwang-Back Kim**

*Dong-A Univ., Silla Univ.

ABSTRACT

RBF 네트워크의 중간층은 클러스터링 하는 층으로 주어진 자료 집합을 유사한 클러스터들로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터로 분류하고 정해진 반경 내에 존재하지 않으면 다른 클러스터로 분류한다. 그러나 정해진 반경 내에서 클러스터링 하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다. 따라서 본 논문에서는 효율적으로 중간층을 결정하기 위한 방법으로 퍼지 C-Means 클러스터링 알고리즘을 이용하고자 하였다.

그리하여 본 논문에서는 고장 전류의 특성을 해석하여 그 원인을 판단, 분류하기 위하여 전력계통의 고장 기록 장치로부터 얻어지는 선로의 전류 데이터를 FCM을 이용 분류하여 다양한 고장 모드를 판별할 수 있었다.

1. 서론

경제의 성장으로 인한 국내의 전력 수요는 해마다 증가하고 대도시의 인구 집중현상에 따른 전력수요밀도가 크게 작용하고 있는 시점에서, 여러 가지 환경요인으로 인한 송배전 선로의 전력 설비 고장 유형이 다양화 (수목접촉, 외물접촉, 조류, 고층건축물, 절연열화, 산불, 기후, 도로굴착 등) 되어지고 있다. 그러나 이런 고장의 원인을 분석하는 경우 기존의 방법(벡터해석법 등)으로는 그 다양한 원인의 판별이 곤란하여, 원인불명의 처리가 많아지고 있는 실정이다.

이러한 문제를 해결하기 위한 목적으로 최근의 신호처리분야에서 가장 많이 사용되는 기법으로는 Fourier 변환과 Wavelet 변환이 있는데, 이 두 변환은 서로 다른 기저함수를 사용한다. 즉, Fourier 변환은 $e^{-j\omega t}$ 와 같이 연속이며, 무한회 미분 가능한 함수를 사용하는 반면, Wavelet 변환은 기본 Wavelet에 시간적으로도 주파수적으로도 국재화 시키는 함수를 사용한다는 점에서 차이가 있으며, Wavelet 변환은 고주파 성분에 대해서는 시간 분해능이 높고, 저주파 성분에 대해서는 주파수 분해능이 높아지므로, 주어진 신호에 대한 지식이 없이도 시간-주파수 해석이 가능하고, 고주파 성분을 갖는 특이점의 검출에도 적합하게 된다.^[1] 하지만 전력계통에서의 고장전

류의 경우는 시계열 데이터임과 그 형태의 유사성으로 인해 정확한 분류에 어려움이 따른다. 이에 본 논문에서는 RBF 네트워크를 통해 이러한 원인을 분류하기 위한 목적으로 그 중간층을 결정하기 위한 방법으로 퍼지 C-Means 클러스터링 알고리즘을 이용하여 기존의 방법들과 비교하고자 하였다.

2. FCM을 이용한 RBF 네트워크의 중간층 결정

RBF 네트워크는 빠른 학습 속도, 일반화, 단순화의 특징으로 데이터 분류, 비선형 시스템 모델링 등에 많이 적용되고 있다. 신경망의 관점에서 RBF네트워크는 3개의 층으로 구성된 전방향 신경망 형태를 갖추고 있다. 이런 구조적 형태의 특징으로 각 계층이 개별적인 순서를 결정하기 때문에 학습 속도가 다층 퍼셉트론 보다 빠른 특징을 가지고 있다. 전형적인 RBF 네트워크의 구조는 그림1과 같다.




그림1. RBF 네트워크
Fig. 1 RBF Network

여기서 입력층과 중간층간에는 클러스터링하는 역할을 수행하게 된다. 중간층에 있는 노드는 그 자신의 중심을 가지고, 입력 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 에 대하여 자신과의 중심 간의 거리벡터를 구한다. 이 노드의 출력은 거리 벡터에 대한 일정 형태의 비선형 함수로 얻어진다. 입력이 노드의 중심에 가까울수록 그 출력값은 커지게 된다. 중간층을 구하는 것은 식(1)과 같다.

$$\rho_k = \exp\left(-\frac{\|X - C_k\|^2}{\sigma_k^2}\right) \quad (1)$$

여기서 c 는 각 클러스터의 중심값이고 σ 는 중심에 대한 넓

이 값이 된다. 중간층과 출력층간에는 일반적인 학습 과정을 수행한다. RBF 네트워크의 출력노드는 각 중간층 노드의 출력값에 학습과정 중 가변인 연결가중치를 곱한 후 이들을 더한 값을 그 출력값으로 갖는다. 그리고 식(2)와 같이 지도학습과 동일한 형태로서 목표값과 출력값 간의 오차값을 최소화하는 방향으로 학습한다.

$$y_i = \sum_{k=1}^M \rho_k w_{kj} \quad (2)$$

하지만 RBF 네트워크는 학습이 완료된 상태 즉, 연결강도가 특정 값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습시키는데 상당한 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류해버리는 단점이 있다.

3. RBF 네트워크를 위한 FCM 클러스터링

퍼지 RBF 네트워크에서 제안하는 중간층의 클러스터링 방법은 기존의 이분법과는 달리 퍼지 분류인 1개의 데이터가 2가지 이상의 클러스터에 속하는 것을 허용한다. 퍼지 논리의 특징을 이용하여 이분법에 의한 ART1 알고리즘을 적용한 방법보다 효율적이고 정확성이 높은 중간층을 구성하기 위하여 본 논문에서는 퍼지 C-Means 알고리즘을 적용한 퍼지 RBF 네트워크를 제안한다.

본 논문에서는 RBF 네트워크의 중간층에 FCM 알고리즘을 적용하였는데, FCM 알고리즘은 각각의 데이터와 각각의 클러스터 중심과의 거리에 대한 유사도 측정을 기반으로 목적함수 식(3)을 최적화시키기 위한 알고리즘이다. 본 논문에서 적용한 FCM알고리즘은 식(4), 식(5)와 같다.

$$J_m(U, v) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m |x_k - v_i|^2 \quad (3)$$

$$u_{ik} = 1 / \sum_{j=1}^c \left(\frac{|x_k - v_i|^2}{|x_k - v_j|^2} \right)^{1/m-1} \quad (4)$$

$$v_i = \sum_{k=1}^n (u_{ik})^m x_k / \sum_{k=1}^n (u_{ik})^m \quad (5)$$

여기서 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 는 입력 데이터이며 u_{ik} 는 x_k 가 클러스터 i 에 속한 정도를 나타낸다. 그리고 v_i 는 i 번째 클러스터의 중심이다. FCM 알고리즘은 다음과 같다.

- step 1. c, m , 역치값(ϵ)를 설정
- step 2. (0) 값을 초기화
- step 3. 클러스터의 중심값 (p) 를 식(5)에 따라 설정
- step 4. $(p+1)$ 를 식(4)에 따라 설정.
- step 5. $\| (p) - (p+1) \| \leq \epsilon$ 이 될 때까지 step 3부터 반복한다.

4. 자료취득장치의 구성도

송전선로의 고장 전류 자료 취득 장치는 F/R(고장기록장치)로서 그림 2와 그림 3과 같다.

F/R(Fault Recorder)은 전력설비에 취부되어 있는 PT(전압-변성기)와 CT(전류-변류기)의 2차 출력 값(전압 : 63.5/ 115V/ 190V, 전류 : 5A)으로 고장 발생시 정보를 취득하여 저장 및 Local 출력하여 주는 장치로서 전압전류 파형 AC Channel 16/32, DC Channel(on-off접점) 32/64로 구성 되어 있다.




그림 2. 자료 취득 장치 구성도
Fig. 2. Block diagram of Fault Recorder



그림 3. 고장기록장치(TR-2132)
Fig. 3. Fault Recorder(TR-2132)

또한 그림 4에서 보여지는 것과 같이 통신(TCP/IP방식)의 Dial-up Modem통하여 원거리에서도 자료를 취득하여 분석 할 수 있다.




그림 4. 자료취득 장치와 연결통신망
Fig. 4. Fault Recorder and Network

이러한 일련의 과정을 통해 고장이 발생한 경우 현재는 그림 5-6에서와 같이 순시전류의 파형과 주파수를 통해 고장의 발생을 알 수는 있으나 그 원인을 찾는 것은 어려워 선로 순시원들에 의해 직접적으로 고장의 원인을 찾는 방법이 사용되어진다.

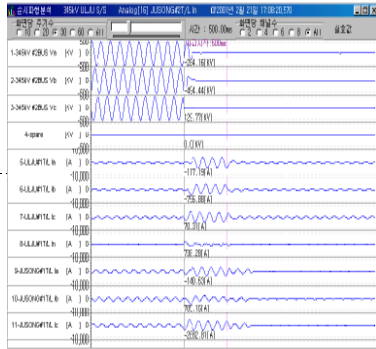


그림 5. 시간영역에서의 고장 데이터
Fig. 5. Fault Data in Time Domain

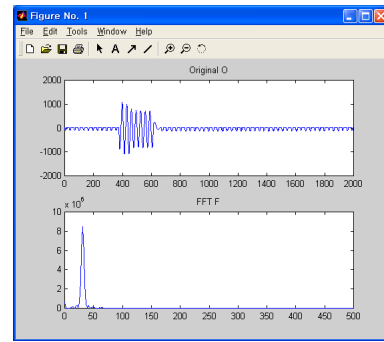


그림 9. 절연파괴사고파형의 FFT 결과
Fig. 9 Result of FFT under isolation destruction

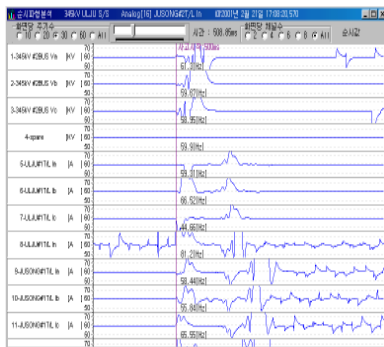


그림 6. 주파수 영역에서의 고장 데이터
Fig. 6. Fault Data in Frequency Domain




그림 9. 절연파괴사고파형의 전처리
Fig. 9 Preprocess of isolation destruction waveform

5. 결과 및 결론

본 논문에서 제안한 FCM에 의한 고장전류의 분석 결과 및 분류의 가능성에 관한 결과는 다음과 같다.

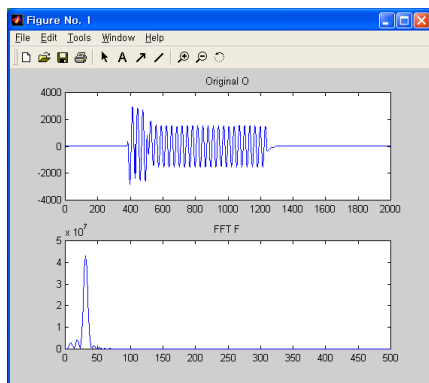


그림 7. 섬락사고파형의 FFT 결과
Fig. 7. Result of FFT under Flashover




그림 8. 섬락사고 파형의 전처리
Fig. 8 Preprocess of Flashover waveform

FCM의 적용을 위하여서는 고장전류의 시계열 데이터를 FCM의 입력을 위한 하나의 데이터로 특징 지워야 하는데 시계열 데이터임을 감안하여 고장 전류가 나타나는 사이클 동안의 고장 전류 데이터를 전처리를 하여 사용하였다. 이를 위하여 고장 전류분과 고장전류의 변화분에 관해 위상 평면을 구성하여 이를 2X8의 벡터로 구성하여 실험의 입력으로 하여 이를 구현 하였다. 다음의 그림 7에서 그림 10은 실험한 파형들 중의 일부분으로 전처리의 결과 FCM의 중간층의 클러스터링 방법으로서의 가능성 및 개연성을 확인할 수 있었다.

모의 실험 결과 ART기반 RBF 네트워크에 비하여 FCM 기반 퍼지 RBF 네트워크가 중간층의 노드수의 생성을 최소화하여 반복횟수를 줄임으로서 시간적인 면에서의 효율성 및 그 분류에서 더욱더 우수한 특성을 나타냄을 확인할 수 있었다.

향후 본 실험에서의 결과를 바탕으로 확인되어진 FCM에 의한 클러스터링을 기저로 개선된 FCM 클러스터링 기법 및 RBF 네트워크가 아닌 개선된 신경망과의 조합을 통하여 다양한 사고패턴 인식이 적용하여 그 학습 성능을 분석하여 더욱더 인식율을 높이고자 한다.

참고 문헌

- [1] 이준탁, 정종원, "웨이블릿 변환을 이용한 전력시스템 고장 전류의 판별", 조명·설비학회 논문지, 제21권 3호, pp.75-81, 2007, 3월.
- [2] R.L. Cannon, J.V. Dave, and J.C. Bezdek, "Efficient Implementation of Fuzzy C Means Clustering Algorithm," IEEE Trans. Pattern Anal. & Machine Int., Vol. PAMI-8, No.2, pp248-255, 1986.